

Imputace nulových hodnot v metabolomice

Alžběta Gardlo^a, Matthias Templ^b, Karel Hron^c, Peter Filzmoser^b

alzbetagardlo@gmail.com

^a Laboratoř metabolomiky, Ústav molekulární a translační medicíny,
Přírodovědecká fakulta, UPOL,
Fakultní nemocnice Olomouc;

^b Vienna University of Technology, Austria;

^c Přírodovědecká fakulta, UPOL.

Robust, 13.9. 2016



FAKULTNÍ NEMOCNICE
OLOMOUC



Obsah

1 Metabolomika


2 Kompoziční data

3 Imputace nulových hodnot

4 Simulační studie

5 Závěr

Metabolomika



(Wu et al., 2011)

Pivotové isometrické logratio (ilr) souřadnice

- Chceme vytvořit ortonormální bázi vzhledem k Aitchisonově geometrii, ve které první ilr souřadnice vysvětluje veškerou důležitou informaci o zvolené složce.
- Máme kompoziční matici $\mathbf{X}_{n \times D} = (\mathbf{x}_1, \dots, \mathbf{x}_D)$.
Přeuspořádaná kompozice s l -tým prvkem, $l = 1, \dots, D$, posunutým na první pozici je označena jako
 $\mathbf{X}^{(l)} = (\mathbf{x}_l, \mathbf{x}_1, \dots, \mathbf{x}_{l-1}, \mathbf{x}_{l+1}, \dots, \mathbf{x}_D) =$
 $(\mathbf{x}_1^{(l)}, \mathbf{x}_2^{(l)}, \dots, \mathbf{x}_l^{(l)}, \mathbf{x}_{l+1}^{(l)}, \dots, \mathbf{x}_D^{(l)})$.

Pivotové ilr souřadnice

$$z_i^{(l)} = \sqrt{\frac{D-i}{D-i+1}} \ln \frac{x_i^{(l)}}{\sqrt[D-i]{\prod_{j=i+1}^D x_j^{(l)}}}, \quad i = 1, \dots, D-1. \quad (1)$$

Druhy nulových hodnot

- **Chybějící hodnoty**

- Hodnota chybí z nějakého důvodu - nelze změřit, respondent neodpověděl na otázku.
- Nahrazení rozumnou hodnotou.
- V metabolomice se nevyskytují často.

- **Zaokrouhlené nuly**

- Vznikají zaokrouhlováním dat blízkých nule nebo díky tzv. **detekčnímu limitu přístroje**.
- Citlivost každého přístroje má své limity (detekční limit - DL) - hodnoty pod DL jsou vyhodnoceny jako nula, i když by měly být přítomny nějaké koncentrace.
- Je třeba nahradit s ohledem na DL.
- Časté v metabolomice, zejména při použití tzv. necíleného přístupu.

Imputace zaokrouhlených nul

- Většina současných statistických metod není schopna pracovat s nulovými hodnotami → potřeba imputace.
- Současné metody nahrazování:
 - Nahrazení nulových hodnot $2/3$ limitu detekce nebo jinou vhodně zvolenou konstantou - často užívané, ale ignoruje mnohorozměrnou strukturu dat a podhodnocuje kovarianční strukturu.
 - Metoda založená na k nejbližších sousedech - mnohorozměrná, ale pořád ne zcela ideální.

Imputace zaokrouhlených nul - přístupy

- Balíček *zCompositions* v softwaru R.
- **Multiplicative replacement (mult repl)** - nahrazení pomocí části DL (např. 2/3 DL).
- **Multiplicative log-normal replacement (mult lognorm)** - nahrazení nul s využitím multiplikativního lognormálního rozdělení.
- **Multiplicative Kaplan-Meier smoothing spline replacement (mult KMSS)** - nahrazení pomocí geometrického průměru náhodného výběru z kubické vyhlazovací funkce (odpovídá inverzi Kaplan-Meierovy EDF).
- **Log-ratio data augmentation algorithm (lr da)** - využití Markov chain Monte Carlo přístupu pro aditivní logratio (alr) souřadnice.

Imputace zaokrouhlených nul - přístupy

- **Additive log-ratio EM algorithm (lr em)** - postupné využití EM algoritmu pro alr souřadnice.
- **PLS** - využití pivotových ilr souřadnic a metody dílčích nejmenších čtverců - bere v úvahu kompoziční podstatu dat i existenci DL (více v posteru).
- **Pre-selection of variables and model-based replacement of rounded zeros (method varOLS)** - využívá variační matici pro výběr proměnných a redukci dimenze dat.

Validační kritéria

1 Average difference in covariance structure (ADCS)

$$ADCS = \sqrt{\frac{1}{(D-1)^2} \sum_{i=1}^{D-1} \sum_{j=1}^{D-1} (s_{ij} - s_{ij}^*)^2} = \frac{1}{D-1} \|\mathbf{S} - \mathbf{S}^*\|_F,$$

kde $*$ označuje imputovanou matici, \mathbf{S} je výběrová kovarianční matici, $\|\cdot\|_F$ je Frobeniova maticová norma.

2 Compositional error deviation (CED)

$$\frac{\frac{1}{n_M} \sum_{k \in M} d_a(\mathbf{x}_k, \mathbf{x}_k^*)}{\max_{\{\mathbf{x}_i, \mathbf{x}_j \in \mathbf{X}\}} \{d_a(\mathbf{x}_i, \mathbf{x}_j)\}},$$


Aitchisonova vzdálenost dvou kompozic \mathbf{x} a $\tilde{\mathbf{x}}$:

$$d_A(\mathbf{x}, \tilde{\mathbf{x}}) = \left[\frac{1}{D} \sum_{i=1}^{D-1} \sum_{j=i+1}^D \left(\log \frac{x_i}{x_j} - \log \frac{\tilde{x}_i}{\tilde{x}_j} \right)^2 \right]^{1/2}.$$


Simulační studie

- Normální rozdělení na simplexu (výběrovém prostoru kompozic).
- 1 Nízko-dimenzionální scénář:** datová matice \mathbf{X} s $n = 50$ pozorováními a $D = 16$ proměnnými. Podíl hodnot pod DL (nul) je v rozpětí od 0 do 0.3, ty jsou v každé druhé proměnné.
- 2 Vysoko-dimenzionální scénář:** datová matice \mathbf{X} s $n = 50$ pozorováními a $D = 128$ proměnnými. Podíl nul stejný jako v nízko-dimenzionálním scénáři.
- 3 10% zaokrouhlených nul, rozdílné dimenze:** datová matice \mathbf{X} s $n = 50$ pozorováními a měnícím se počtem prvků kompozice (2, 4, 8, 16, 32, 64, 128, 256).


Simulační studie - Nízko-dimenzionální scénář



Simulační studie - Vysoko-dimenzionální scénář



Simulační studie - Rozdílné dimenze



Závěr

- Častý výskyt zaokrouhlených nul v metabolomických datech
→ potřeba jejich imputace.
- Současně používané metody nahrazení (např. použití 2/3 detekčního limitu) nefungují korektně.
- Výhodné použití metody, která kombinuje přístup logratio metodiky a metody dílčích nejmenších čtvrců - je zachována mnohorozměrná povaha kompozičních dat.

Literatura

-  M. Templ, K. Hron, P. Filzmoser, **A. Gardlo**. Imputation of rounded zeros for high-dimensional compositional data. *Chemometrics and Intelligent Laboratory Systems*, 155:183-190, 2016.
-  J. Aitchison. *The Statistical Analysis of Compositional Data*. Chapman & Hall, London, 1986.
-  B. Walczak, D.L. Massart. Dealing with missing data. Part I. *Chemometrics and Intelligent Laboratory Systems*, 58:15-27, 2001.
-  J.A. Martín-Fernández, K. Hron, M. Templ, P. Filzmoser, J. Palarea-Albaladejo. Model-based replacement of rounded zeros in compositional data: Classical and robust approaches. *Computational Statistics & Data Analysis*, 56(9):2688-2704, 2012.
-  K. Hron, M. Templ, P. Filzmoser. Imputation of missing values for compositional data using classical and robust methods. *Computational Statistics & Data Analysis*, 54(12):3095-3107, 2010.
-  L. Najdekr, **A. Gardlo**, L. Mádrová, D. Friedecký, H. Janečková, E.S. Correa, R. Goodacre, and T. Adam. Oxidized phosphatidylcholines suggest oxidative stress in patients with medium-chain acyl-coa dehydrogenase deficiency. *Talanta*, 139:62-66, 2015.